

Автоматизована система розпізнавання повітряних цілей за допомогою згорткових нейронних мереж

Automated system for recognizing air targets using convolutional neural networks

Олег Лавров

Corresponding author: к. тех. н., заступник начальника науково-дослідного відділу, e-mail: lavrov1107@gmail.com, ORCID: 0000-0003-1292-5986

Андрій Лавров

старший науковий співробітник науково-дослідного відділу, e-mail: andriy.lavrov@gmail.com, ORCID: 0009-0004-1138-2945

Oleg Lavrov

Corresponding author: PhD in Technical Sciences, Deputy Head of the Research Department, e-mail: lavrov1107@gmail.com, ORCID: 0000-0003-1292-5986

Andrii Lavrov

Senior Researcher in the Research Department, e-mail: andriy.lavrov@gmail.com, ORCID: 0009-0004-1138-2945

Харківський національний університет Повітряних Сил імені Івана Кожедуба, м. Харків, Україна

Ivan Kozhedub Kharkiv National Air Force University, Kharkiv, Ukraine

Received: August 13, 2025 | Revised: August 29, 2025 | Accepted: August 31, 2025

DOI: <https://doi.org/10.33445/sds.2025.15.4.16>

Мета роботи. Підвищення ефективності і точності систем протиповітряної оборони шляхом розробки та впровадження автоматизованої системи розпізнавання повітряних цілей із використанням методів глибокого навчання, зокрема згорткових нейронних мереж.

Метод дослідження. Застосовано кількісний підхід із використанням публічного набору даних Drone Image Classification Dataset, що містить чотири класи зображень (три типи дронів та негативний клас).

Результати дослідження. Розроблена модель показала високу точність класифікації повітряних цілей у тестових умовах, забезпечивши надійну ідентифікацію дронів та стійкість до фонових перешкод.

Теоретична цінність дослідження. Поглиблено наукове розуміння можливостей використання згорткових нейронних мереж у завданнях реального часу з розпізнавання повітряних об'єктів, що сприяє розвитку теорії комп'ютерного зору у сфері безпілотних літальних апаратів.

Практична цінність дослідження. Отримані результати можуть бути використані для розробки та вдосконалення систем ППО, охорони стратегічних об'єктів та захисту критичної інфраструктури.

Оригінальність дослідження. Запропоновано ефективну архітектуру CNN для багатокласової класифікації повітряних цілей із використанням публічного датасету, що враховує негативний клас для підвищення стійкості системи.

Обмеження дослідження. Модель тестувалася на статичних зображеннях; для підвищення її ефективності в реальних умовах доцільно дослідити роботу з відеопотоками та застосування методів оптимізації обчислювальних ресурсів для вбудованих систем.

Тип статті. Прикладне дослідження.

Purpose. To enhance the efficiency and accuracy of air defense systems through the development and implementation of an automated air target recognition system based on deep learning methods, specifically convolutional neural networks (CNNs).

Method. A quantitative approach was applied using the public Drone Image Classification Dataset containing four image classes (three types of drones and a negative class).

Findings. The developed model demonstrated high classification accuracy of air targets under test conditions, ensuring reliable drone identification and robustness against background noise.

Theoretical implications. The research deepens the scientific understanding of applying convolutional neural networks to real-time air object recognition tasks, contributing to the advancement of computer vision theory in the field of unmanned aerial vehicles.

Practical implications. The obtained results can be utilized for the development and improvement of air defense systems, strategic facility protection, and critical infrastructure security.

Originality of the study. An effective CNN architecture for multi-class air target classification using a public dataset has been proposed, incorporating a negative class to improve system robustness.

Research limitations. The model was tested on static images; to improve its real-world performance, further research should address video stream processing and computational optimization methods for embedded systems.

Paper type. Applied research.

Ключові слова: згорткова нейронна мережа, дрони, розпізнавання повітряних цілей, обробка зображень, автоматизована система.

Key words: convolutional neural network, drones, air target recognition, image processing, automated system.

Вступ

Сучасні виклики у сфері забезпечення безпеки повітряного простору обумовлюють нагальну потребу у створенні високотехнологічних автоматизованих систем розпізнавання повітряних цілей.

Швидкий розвиток безпілотних літальних апаратів (БПЛА, дронів) різних класів, а також складних типів бойових літаків, а також загроза їх несанкціонованого використання роблять завдання ідентифікації повітряних об'єктів особливо актуальним для оборонної галузі.

Водночас традиційні методи класифікації та моніторингу повітряних об'єктів часто поступаються сучасним підходам штучного інтелекту у швидкості обробки великих обсягів даних та точності прогнозування. Особливої уваги потребують малі повітряні цілі, такі як комерційні та саморобні дрони, які все частіше використовуються у військових і цивільних конфліктах.

Теоретичні основи дослідження

Patil та інші (2025) запропонували оригінальний підхід до класифікації форм на основі акустичного розсіювання із використанням нейронних мереж, натренованих на синтетично згенерованих даних. Результати показали, що навіть за наявності обмеженої кількості експериментальних спостережень мережа здатна досягати високих показників точності при розпізнаванні складних контурів об'єктів. Це особливо важливо для задач пасивного виявлення дронів за допомогою акустичних сенсорів у реальному середовищі, де сигнал часто спотворюється шумом і перешкодами.

У свою чергу Chen та інші (2024) зосередили увагу на мультифідельному підході оптимізації аеродинамічних форм із використанням глибинних нейронних мереж та знання-орієнтованого вибору зразків. Вони довели, що їхній метод дозволяє зменшити обсяг дорогих високоточних симуляцій, водночас зберігаючи якість оптимізації. Це напряму співвідноситься з потребами дронобудування: оптимізація форми БПЛА під конкретні задачі (наприклад, максимальна дальність чи маневреність) може суттєво виграти від таких гібридних моделей.

Lee та інші (2025) представили підхід до детекції структурних пошкоджень за акустичними емісіями у реальному часі. Вони розробили глибоку CNN, яка у поєднанні з алгоритмами виділення спектральних ознак досягла точності класифікації понад 95% при ідентифікації тріщин і мікродефектів у складних структурах. Для безпілотних систем це відкриває можливість безперервного моніторингу технічного стану елементів каркасу під час польоту.

Водночас Ahmed та інші (2024) у своїй роботі зосередилися на гібридних архітектурах, що поєднують CNN із рекурентними мережами (RNN). Їхній підхід до діагностики несправностей обертових механізмів довів, що комбінація просторової та часової обробки сигналів дозволяє досягти точності діагностики понад 98% навіть за шумних виробничих умов. Це особливо цінно для розпізнавання дронів, що можуть мати обертові частини, наприклад, багатогвинтові системи.

Дослідження Wang та інші (2025) висвітлює перспективи інтеграції фізичних обмежень у структуру нейронних мереж для розв'язання обернених задач у структурній динаміці. Їхня фізично-обґрунтована модель (PINN) дозволила значно зменшити похибки між симульованими і фактичними результатами, що критично важливо для завдань моделювання аеродинамічної поведінки дронів у мінливих погодних умовах або при виявленні їх у складних фонів.

У дослідженні Kumar та інших (2024) представлена ансамблева архітектура глибинних моделей для виявлення дефектів у підшипниках. Вони показали, що поєднання кількох нейронних мереж дозволяє досягти точності понад 99% у складних робочих умовах. Це демонструє потенціал використання ансамблевих підходів у класифікації повітряних цілей, де може знадобитися обробка даних з різних сенсорів — відео, акустики, радіолокації.

Li та інші (2024) запропонували метод ідентифікації пошкоджень балкових конструкцій за допомогою автоенкодерів, що дозволяє працювати з великими обсягами неструктурованих даних. Їхній метод показав ефективне виявлення прихованих дефектів навіть у разі низької інтенсивності сигналу, що близько до задач виявлення малопомітних дронів серед складного фону.

У роботі Zhang та інших (2025) CNN моделі використовувались для прогнозування втомного ресурсу металевих матеріалів. Автори досягли зниження середньоквадратичної похибки на понад 15% у порівнянні з традиційними підходами, що особливо важливо для

визначення залишкового ресурсу конструкцій безпілотників, які можуть працювати у жорстких умовах експлуатації.

Park та інші (2024) зосередилися на визначенні ударних навантажень у композитних структурах за допомогою CNN. Їхній метод дозволяє відслідковувати локальні пошкодження в режимі реального часу, що прямо відповідає вимогам до оцінки бойової готовності БПЛА після експлуатації у складних умовах.

Nguyen та інші (2024) реалізували фреймворк глибинного навчання для моніторингу мостів у реальному часі з використанням даних прискорень. Вони досягли точності понад 95% у прогнозуванні стану конструкцій при навантаженні. Аналогія з БПЛА очевидна: моделі з онлайн-моніторингом можуть забезпечувати оцінку стану дронів під час виконання польотів, що підвищує надійність їх використання.

Zhao та інші (2025) акцентували увагу на застосуванні трансферного навчання для виявлення пошкоджень за обмежених даних. Вони показали, що перенавчання моделей дозволяє підвищити точність прогнозування на 12% у порівнянні зі стандартними моделями. Це напряму пов'язано з практичним викликом розпізнавання нових типів дронів у реальних умовах, коли обсяг навчальних даних обмежений.

Liu та інші (2025) запропонували комбінацію глибинних мереж із вейвлет-перетворенням, що дозволяє виділяти дрібномасштабні ознаки ушкоджень у складних конструкціях. Їхня модель досягла точності понад 96% при мінімальній кількості попередньої обробки сигналу. Wang та співавт. (2025) успішно продемонстрували застосування CNN для моніторингу мостів під навантаженням рухомого транспорту, досягнувши стабільності прогнозу у режимі реального часу з точністю понад 97%. Це ще раз підкреслює можливість CNN працювати у динамічних умовах та обробляти великі потоки даних.

Постановка проблеми

Узагальнення представлених результатів свідчить про високий потенціал глибинних нейронних мереж у різних галузях моніторингу складних технічних об'єктів. Однак при цьому більшість досліджень не зосереджується безпосередньо на розпізнаванні малогабаритних повітряних цілей, зокрема дронів, у складних середовищах з високим рівнем шуму або мінливими погодними умовами. Це визначає актуальність запропонованої розробки, що спрямована на створення гнучкої та масштабованої CNN-системи для автоматизованого розпізнавання дронів із можливістю подальшої адаптації до різних сценаріїв застосування.

Метою роботи є розробка та апробація автоматизованої системи розпізнавання повітряних цілей, зокрема безпілотних літальних апаратів (дронів) із використанням згорткових нейронних мереж, яка забезпечує класифікацію типів повітряних об'єктів, передусім різних типів дронів, у реальному або наближеному до реального часу. Запропонована система має продемонструвати стійкість до різних умов знімання, бути придатною для інтеграції у практичні комплекси спостереження та протиповітряної оборони, а також мати архітектуру, що легко масштабується для подальшого донавчання під специфічні типи цілей.

Методологія дослідження

Для того щоб обґрунтувати працездатність запропонованого підходу та перевірити можливість ефективної класифікації типів повітряних об'єктів у режимі, наближеному до реального часу, було проведено серію експериментів із використанням згорткової нейронної мережі (CNN). Головною метою було продемонструвати, що навіть порівняно проста архітектура CNN здатна вирішувати завдання розпізнавання дронів різних типів у змінних умовах знімання та відокремлювати їх від фонових сцен, у яких об'єкт відсутній.

У якості навчальної та тестової вибірки використано відкритий Drone Image Classification Dataset, що спеціально сформований для задач класифікації цивільних безпілотних літальних апаратів за візуальними ознаками. Цей датасет охоплює чотири окремі класи: DJI Inspire, DJI Mavic, DJI Phantom та No Drone. Три перші класи відповідають різним комерційним моделям дронів, що на практиці відрізняються за габаритами, формами, конфігураціями гвинтів і конструктивними особливостями, що створює різноманітність у вигляді контурів та характерних ознак на зображеннях. Четвертий клас No Drone сформовано як негативний, він містить зображення типових фонових сцен — фрагментів неба, міського або природного середовища без присутності будь-яких повітряних об'єктів. Наявність такої контрольної групи особливо важлива для підготовки моделі, яка має не лише розпізнавати присутність дрона, але й з високою достовірністю ідентифікувати його відсутність, мінімізуючи хибнопозитивні спрацювання у реальних умовах експлуатації.

Дані у межах кожного класу підібрані так, щоб максимально врахувати варіативність зовнішніх факторів. Зокрема, зображення включають різні кути зйомки — як фронтальні, так і з верхніх, бічних і діагональних перспектив. Це дозволяє моделі навчитися виділяти стабільні контурні та текстурні ознаки незалежно від положення дрона у кадрі, що є критично важливим для систем, які працюють у режимі безперервного моніторингу. Окрім різних ракурсів, у вибірці представлені зображення з різною якістю освітлення: зйомки вдень при ясному небі, у хмарних умовах та при частковому затемненні об'єкта. Таке різноманіття забезпечує підвищення стійкості моделі до змін зовнішнього середовища, які є типовими для реального театру спостереження повітряного простору.

З технічної точки зору датасет структуровано за принципом розподілу на дві логічні частини: навчальну (train) та валідаційну (val). Це відповідає кращим практикам машинного навчання, де навчальна підмножина використовується для оптимізації параметрів мережі, а валідаційна дозволяє об'єктивно оцінювати узагальнюючу здатність моделі на прикладах, які не використовувалися під час навчання. Кожен підрозділ організовано у вигляді ієрархії директорій за назвами класів, що спрощує завантаження даних через генератори ImageDataGenerator у середовищі TensorFlow/Keras та полегшує процес аугментації, масштабування й нормалізації зображень.

Додатковим аргументом на користь вибору саме цього датасету є його висока якість та достатній обсяг, що дозволяє уникнути переобучення при збереженні відносно компактної архітектури моделі. Формат зображень дозволяє легко підлаштовувати їх під стандартизовані вхідні розміри CNN, а наявність чітких класів без перетинів мінімізує ймовірність семантичних помилок під час навчання. При цьому клас No Drone виконує роль потужного засобу формування так званої фонові чутливості — здатності моделі диференціювати релевантні об'єкти від шумових та нефункціональних даних.

Обраний датасет не лише відповідає технічним вимогам до збалансованості та різноманітності вибірки, але й імітує реалістичні умови, що наближає процес тестування до умов реальної експлуатації автоматизованих систем протиповітряного спостереження. Це робить Drone Image Classification Dataset доцільною та виправданою основою для побудови й апробації експериментальної моделі.

Результати

Для вирішення поставленої задачі було реалізовано згорткову нейронну мережу, яка складається з трьох основних блоків згорткових шарів з функціями активації ReLU, шарів підвибірки (MaxPooling) та повнозв'язної частини з додатковим шаром Dropout для запобігання перенавчанню (див. фрагмент коду у файлі main.py). Вихідний шар має чотири нейрони, що відповідають кількості класів, і використовує функцію активації softmax для багатокласової класифікації. Архітектура моделі обрана так, щоб балансувати між достатньою

глибиною для виділення інформативних ознак та низькою обчислювальною складністю, що дозволяє використовувати модель у сценаріях з обмеженими ресурсами, наприклад, на вбудованих обчислювальних модулях дронів чи ППО.

Математично робота CNN ґрунтується на згортковій операції, що описується виразом:

$$Z_{i,j}^{(k)} = (X * K^{(k)})_{i,j} + b^{(k)}, \quad (1)$$

де X – вхідне зображення або ознакові карти попереднього шару;
 $K^{(k)}$ – ядро згортки для k -го фільтра;
 $*$ – операція згортки (підхід до застосування CNN для ідентифікації силових впливів у композитних структурах побудованих на основі [9]).

На виході застосовується функція активації ReLU:

$$f(x) = \max(0, x), \quad (2)$$

що забезпечує нелінійність та сприяє кращому наближенню складних залежностей (підхід до застосування ReLU в архітектурі для задач моніторингу в реальному часі побудований на основі [3]). Завдяки таким обчислювальним блокам модель послідовно перетворює вихідні піксельні дані у набір високорівневих ознак, які в подальшому класифікуються у відповідні типи повітряних цілей.

Обрана структура та принципи функціонування дозволяють запропонованій системі демонструвати гнучкість при роботі з різними типами даних та спрощують інтеграцію моделі у реальні комплекси автоматизованого спостереження за повітряним простором.

Для реалізації поставленої мети було розроблено повноцінний експериментальний цикл, що включає етапи підготовки даних, побудови архітектури згорткової нейронної мережі, процесу навчання, оцінювання якості роботи моделі та організації візуалізації результатів.

На першому етапі було здійснено підключення та первинну обробку даних. Було використано можливості стандартного генератора зображень ImageDataGenerator з бібліотеки TensorFlow Keras, що дозволило виконати масштабування піксельних значень до діапазону [0; 1] для уніфікації шкали ознак та зниження ризику нестабільності градієнтів під час навчання. Усі зображення було приведено до єдиного розміру 150 × 150 пікселів, що забезпечує баланс між збереженням інформативності та швидкістю обробки даних у процесі згортки. Розмір пакету (batch size) було встановлено рівним 32, що дало змогу забезпечити оптимальний компроміс між стабільністю оптимізації та використанням пам'яті відеокarti.

На другому етапі було реалізовано послідовну архітектуру моделі (Sequential API). Було передбачено три каскади згорткових шарів (Conv2D) з функціями активації ReLU, кожен з яких супроводжується шарами підвибірки (MaxPooling2D). Зокрема, було налаштовано:

перший згортковий блок із 32 фільтрами та ядром 3×3,

другий — із 64 фільтрами,

третій — із 128 фільтрами, що дозволило моделі послідовно виділяти як базові, так і високорівневі ознаки.

Після каскаду згортки було здійснено розгортання багатовимірного тензора у вектор (Flatten), який передавався до повнозв'язного шару (Dense) з 128 нейронів та активацією ReLU. Для запобігання перенавчанню було впроваджено шар Dropout із коефіцієнтом 0.5, що вимикає 50% нейронів на кожній ітерації навчання. Вихідний шар було спроектовано як багатокласовий softmax з 4 нейронами, що відповідають кількості класів у вибірці (DJI Inspire, DJI Mavic, DJI Phantom, No Drone).

Для оптимізації параметрів моделі було застосовано алгоритм Adam, що забезпечує адаптивну швидкість навчання та стабільність сходження. В якості функції втрат було обрано

категоріальну крос-ентропію, що є стандартною для багатокласової класифікації. Тривалість навчання було обмежено 10 епохами для демонстраційних цілей, однак структура дозволяє масштабувати цей параметр для підвищення точності у подальших експериментах.

Логіка функціонування запропонованої програми наведена на рис. 1.




Рисунок 1 – Логічна структура роботи автоматизованої системи розпізнавання повітряних цілей

Джерело: побудовано автором

На основі розробленого коду було реалізовано послідовний алгоритм роботи, що включає такі ключові етапи:

1. Було ініціалізовано службові директорії `models/` і `results/` для збереження моделі та проміжних артефактів.

2. Було сформовано генератори потоків даних із автоматичною подачею батчів, масштабуванням та перетворенням зображень у тензорний формат.

3. Було здійснено повний цикл навчання моделі, під час якого ваги мережі оптимізувалися за допомогою зворотного поширення помилки та градієнтного спуску.

4. Після завершення навчання модель було серіалізовано у форматі HDF5 (.h5), що дозволяє зберегти архітектуру та ваги для повторного використання без необхідності повторного тренування.

5. Для контролю якості було побудовано графіки зміни точності (accuracy) та функції втрат (loss) на кожній епосі.

6. Було розраховано та візуалізовано матрицю змішування (confusion matrix), що демонструє співвідношення правильних і хибних класифікацій для кожного класу.

7. Для валідації наочної працездатності мережі було сформовано підсумкове вікно з випадково відібраними 10 зображеннями, для кожного з яких модель здійснила прогноз із виведенням передбаченого класу та рівня впевненості.

Було розроблено компактну, але функціонально достатню архітектуру згорткової нейронної мережі, що може застосовуватися як базова структура для подальшого

нарощування складності та інтеграції у практичні системи моніторингу повітряного простору з акцентом на автоматизоване розпізнавання дронів.

Для перевірки працездатності розробленої згорткової нейронної мережі було проведено серію експериментів, результати яких демонструють відповідність моделі поставленим вимогам з точки зору точності класифікації, стійкості роботи у змінних умовах та здатності ідентифікувати об'єкти малої розмірності.

У першу чергу було здійснено кількісний аналіз зміни функції втрат (loss) протягом 10 епох навчання. Як видно з графіка (рис. 2), крива функції втрат для навчальної вибірки демонструє стабільне зниження від початкового значення близько 0,52 до рівня близько 0,03, що вказує на ефективне навчання моделі без значних коливань чи ознак дивергенції. Для валідаційної вибірки значення втрат протягом навчання зберігаються у межах від 0,18 до 0,1, що свідчить про відсутність значного перенавчання та достатню узагальнюючу здатність моделі.




Рисунок 2 – Динаміка функції втрат під час навчання та валідації

Джерело: побудовано програмним рішенням, розробленим автором

Додатково було оцінено динаміку точності класифікації (accuracy) на кожній епохі. Згідно з отриманими даними (рис. 3), точність на навчальній множині зростає з близько 80 % у першій ітерації до понад 99 % наприкінці циклу, що демонструє ефективне засвоєння ключових ознак дронів і фонових сцен. Точність на валідаційній множині зберігається на рівні 97–98 % протягом останніх епох, що підтверджує стійкість моделі до невідомих даних.




Рисунок 3 – Динаміка точності класифікації під час навчання та валідації

Джерело: побудовано програмним рішенням, розробленим автором

Одним з ключових доказів працездатності є побудова матриці змішування (confusion matrix), яка дозволяє деталізувати розподіл правильних та хибних передбачень по кожному класу (рис. 4). Аналіз матриці свідчить про надзвичайно високу точність класифікації: більшість зображень кожного класу правильно ідентифікуються з незначною кількістю помилок між суміжними класами. Наприклад, для класу DJI Inspire правильно класифіковано 979 випадків із 1000, для DJI Mavic – 992 випадки, що відповідає рівню точності вище 99 %. Клас No Drone також демонструє стабільне розпізнавання з мінімальною кількістю хибнопозитивних спрацювань, що підтверджує спроможність моделі адекватно працювати з фоновими сценами.




Рисунок 4 – Матриця змішування результатів класифікації для чотирьох класів

Джерело: побудовано програмним рішенням, розробленим автором

Окрім кількісних метрик, було проведено візуальний аналіз роботи моделі на реальних зображеннях, що не входили до навчальної множини. Для цього було випадково обрано 10 зображень із усіх класів і виконано передбачення типу об'єкта разом з розрахунком рівня впевненості (рис. 5). Як видно з прикладів, модель із високою ймовірністю (>97% у більшості випадків) відокремлює класи DJI Inspire, DJI Mavic та DJI Phantom навіть за різного рівня розмитості, ракурсу та освітлення. Це наочно демонструє спроможність мережі виділяти ключові просторово-текстурні ознаки дронів навіть у складних умовах, що особливо важливо для реальних систем протиповітряного моніторингу.




Рисунок 5 – Приклади прогнозів моделі для 10 випадкових зображень із відображенням класу та рівня впевненості

Джерело: побудовано програмним рішенням, розробленим автором

Отримані результати демонструють, що запропонована система здатна ефективно вирішувати задачу класифікації дронів навіть на обмеженому наборі вхідних даних та в умовах різних типів спотворень (розмитість, затемнення, низький контраст). Новизна підходу полягає в успішній реалізації гнучкої та легко масштабованої архітектури CNN, орієнтованої саме на виявлення і диференціацію повітряних об'єктів у складних реаліях реального середовища. Додатково, наявність негативного класу *no_drone* у структурі моделі підвищує її прикладну значущість, оскільки забезпечує здатність до фільтрації фонових сцен і зниження кількості помилкових спрацьовувань, що є ключовим у сценаріях реального часу (наприклад, у комплексах ППО або відеоспостереження).

Можна стверджувати, що розроблена модель не лише підтвердила свою функціональну ефективність у задачі розпізнавання дронів, але й є потенційною базою для побудови більш масштабованих систем моніторингу повітряного простору з використанням глибинного навчання.

Висновки

Проведене дослідження продемонструвало, що використання згорткових нейронних мереж (CNN) для автоматизованого розпізнавання повітряних цілей, зокрема безпілотних літальних апаратів, є перспективним напрямом, що має вагоме практичне значення для удосконалення систем моніторингу повітряного простору. На основі запропонованої архітектури було доведено можливість ефективної багатокласової класифікації об'єктів із різними геометричними та конструктивними характеристиками в умовах мінливої видимості та

фонового шуму. Особливо цінною є властивість моделі виявляти відсутність об'єкта за наявності фонових сцен, що істотно знижує ймовірність хибнопозитивних спрацювань і підвищує надійність роботи системи у реальному середовищі.

Одержані результати засвідчили, що навіть при відносно компактній архітектурі й помірному обсязі навчальної вибірки можна досягти високих показників точності та стабільності прогнозування. Це створює умови для подальшої оптимізації моделі під реальні потреби сил протиповітряної оборони та цивільних структур моніторингу. Зокрема, перспективними є напрями адаптації архітектури для роботи на обмежених апаратних ресурсах — мобільних чи автономних комплексах спостереження, інтеграції у складі гібридних систем, які поєднують різномірні датчики: оптичні, акустичні та радіолокаційні.

Водночас результати даної розробки відкривають низку подальших дослідницьких завдань. По-перше, актуальним є розширення набору навчальних даних шляхом залучення реальних зображень дронів із різних джерел, що дозволить підвищити узагальнюючу здатність моделі до нових класів повітряних цілей. По-друге, доцільно розглянути інтеграцію технологій трансферного навчання та фізично обґрунтованих обмежень у структуру мережі, що забезпечить підвищення точності за умови обмеженої кількості розмічених даних. По-третє, значну перспективу становить розробка механізмів адаптивного донавчання безпосередньо під час експлуатації системи у польових умовах — з використанням методів безперервного навчання (continual learning).

Окремо слід підкреслити, що запропонований підхід має потенціал бути масштабованим і мультисенсорним. Це означає можливість розширення архітектури для роботи не лише з фото- чи відеоданими, але й зі складними сигналами акустичного чи радіолокаційного характеру. Такий напрямок відповідає сучасним тенденціям розвитку інтелектуальних систем спостереження, де ключовим є комплексний підхід до збору й обробки інформації з метою досягнення високої точності в умовах багатофакторної невизначеності.

У цілому проведена робота формує підґрунтя для подальших наукових і прикладних досліджень у сфері розпізнавання повітряних цілей із використанням глибинного навчання, що має стратегічне значення для підвищення обороноздатності, безпеки критичної інфраструктури та розвитку високотехнологічних автоматизованих систем у військовій і цивільній авіації.

Фінансування

Це дослідження не отримало конкретної фінансової підтримки.

Конкуруючі інтереси

Автори заявляють, що у них немає конкуруючих інтересів.

Список використаних джерел

1. Patil, G. U., Kwon, H.-S., Epureanu, B. I., & Popa, B.-I. (2025). Synthetically-trained neural networks for shape classification from measured acoustic scattering. *Journal of Sound and Vibration*, 618, 119229. <https://doi.org/10.1016/j.jsv.2025.119229>
2. Chen, Y., Huang, Y., Xu, C., & Zhao, X. (2024). Multi-fidelity surrogate-based shape optimization using deep neural networks and knowledge-based sampling. *Aerospace Science and Technology*, 153, 108932. <https://doi.org/10.1016/j.ast.2024.108932>
3. Lee, J., Choi, J., & Kim, J. (2025). Deep learning-based real-time structural damage detection using acoustic emission. *Engineering Structures*, 310, 117006. <https://doi.org/10.1016/j.engstruct.2025.117006>

4. Ahmed, S., Wang, X., Li, H., & Zhang, Y. (2024). A hybrid deep learning approach for fault diagnosis of rotating machinery. *Measurement*, 226, 113161. <https://doi.org/10.1016/j.measurement.2024.113161>
5. Wang, Q., Liu, Z., Chen, Z., & Xu, B. (2025). Physics-informed neural networks for solving inverse problems in structural dynamics. *Mechanical Systems and Signal Processing*, 205, 110807. <https://doi.org/10.1016/j.ymssp.2024.110807>
6. Kumar, R., Singh, R., Sharma, M., & Patel, S. (2024). An intelligent fault diagnosis method for roller bearings using ensemble deep learning models. *ISA Transactions*, 144, 554–564. <https://doi.org/10.1016/j.isatra.2024.04.015>
7. Li, J., Zhang, L., Wang, T., & Xu, K. (2024). Damage identification of beam structures using deep autoencoder networks. *Structural Control and Health Monitoring*, 31(3), e3039. <https://doi.org/10.1002/stc.3039>
8. Zhang, H., Gao, Y., Li, P., & Sun, W. (2025). Deep learning for fatigue life prediction of metallic materials. *International Journal of Fatigue*, 173, 107848. <https://doi.org/10.1016/j.ijfatigue.2024.107848>
9. Park, S., Kim, Y., Jung, H., & Lee, D. (2024). A convolutional neural network-based approach for impact force identification in composite structures. *Composite Structures*, 328, 116962. <https://doi.org/10.1016/j.compstruct.2023.116962>
10. Nguyen, T., Pham, H., Tran, D., & Bui, T. (2024). Deep learning-based structural health monitoring using acceleration response. *Sensors and Actuators A: Physical*, 361, 114529. <https://doi.org/10.1016/j.sna.2024.114529>
11. Zhao, H., Wang, Y., Chen, M., & Zhou, J. (2025). Transfer learning for damage detection in structures with limited labeled data. *Structural Health Monitoring*, 24(2), 123–136. <https://doi.org/10.1177/14759217231123609>
12. Liu, Y., Li, H., Zhang, J., & Chen, Y. (2025). Structural damage detection based on deep belief networks and wavelet packet decomposition. *Journal of Civil Structural Health Monitoring*, 15(1), 1–14. <https://doi.org/10.1007/s13349-024-00624-2>
13. Wang, J., Xu, Y., Yang, Z., & Hu, J. (2025). A deep learning framework for real-time damage detection of bridges under moving loads. *Computer-Aided Civil and Infrastructure Engineering*, 40(5), 482–499. <https://doi.org/10.1111/mice.12997>
14. Drone type classification. (n.d.). *Kaggle*. URL : <https://www.kaggle.com/datasets/balajikarthek/drone-type-classification>

References

1. Patil, G. U., Kwon, H.-S., Epureanu, B. I., & Popa, B.-I. (2025). Synthetically-trained neural networks for shape classification from measured acoustic scattering. *Journal of Sound and Vibration*, 618, 119229. <https://doi.org/10.1016/j.jsv.2025.119229>
2. Chen, Y., Huang, Y., Xu, C., & Zhao, X. (2024). Multi-fidelity surrogate-based shape optimization using deep neural networks and knowledge-based sampling. *Aerospace Science and Technology*, 153, 108932. <https://doi.org/10.1016/j.ast.2024.108932>
3. Lee, J., Choi, J., & Kim, J. (2025). Deep learning-based real-time structural damage detection using acoustic emission. *Engineering Structures*, 310, 117006. <https://doi.org/10.1016/j.engstruct.2025.117006>
4. Ahmed, S., Wang, X., Li, H., & Zhang, Y. (2024). A hybrid deep learning approach for fault diagnosis of rotating machinery. *Measurement*, 226, 113161. <https://doi.org/10.1016/j.measurement.2024.113161>
5. Wang, Q., Liu, Z., Chen, Z., & Xu, B. (2025). Physics-informed neural networks for solving inverse problems in structural dynamics. *Mechanical Systems and Signal Processing*, 205, 110807. <https://doi.org/10.1016/j.ymssp.2024.110807>

6. Kumar, R., Singh, R., Sharma, M., & Patel, S. (2024). An intelligent fault diagnosis method for roller bearings using ensemble deep learning models. *ISA Transactions*, 144, 554–564. <https://doi.org/10.1016/j.isatra.2024.04.015>
7. Li, J., Zhang, L., Wang, T., & Xu, K. (2024). Damage identification of beam structures using deep autoencoder networks. *Structural Control and Health Monitoring*, 31(3), e3039. <https://doi.org/10.1002/stc.3039>
8. Zhang, H., Gao, Y., Li, P., & Sun, W. (2025). Deep learning for fatigue life prediction of metallic materials. *International Journal of Fatigue*, 173, 107848. <https://doi.org/10.1016/j.ijfatigue.2024.107848>
9. Park, S., Kim, Y., Jung, H., & Lee, D. (2024). A convolutional neural network-based approach for impact force identification in composite structures. *Composite Structures*, 328, 116962. <https://doi.org/10.1016/j.compstruct.2023.116962>
10. Nguyen, T., Pham, H., Tran, D., & Bui, T. (2024). Deep learning-based structural health monitoring using acceleration response. *Sensors and Actuators A: Physical*, 361, 114529. <https://doi.org/10.1016/j.sna.2024.114529>
11. Zhao, H., Wang, Y., Chen, M., & Zhou, J. (2025). Transfer learning for damage detection in structures with limited labeled data. *Structural Health Monitoring*, 24(2), 123–136. <https://doi.org/10.1177/14759217231123609>
12. Liu, Y., Li, H., Zhang, J., & Chen, Y. (2025). Structural damage detection based on deep belief networks and wavelet packet decomposition. *Journal of Civil Structural Health Monitoring*, 15(1), 1–14. <https://doi.org/10.1007/s13349-024-00624-2>
13. Wang, J., Xu, Y., Yang, Z., & Hu, J. (2025). A deep learning framework for real-time damage detection of bridges under moving loads. *Computer-Aided Civil and Infrastructure Engineering*, 40(5), 482–499. <https://doi.org/10.1111/mice.12997>
14. Drone type classification. (n.d.). *Kaggle*. Available from : <https://www.kaggle.com/datasets/balajikartheek/drone-type-classification>